PCT/JP00/03625

02.06.00

JP00/3625

4

日本国特許庁
PATENT OFFICE
JAPANESE GOVERNMENT

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出願年月日
Date of Application: １９９９年　６月　４日

27 JUL 2000

出願番号
Application Number: 平成１１年特許願第１５８４９８号

出願人
Applicant (s): セイコーエプソン株式会社

PRIORITY DOCUMENT
SUBMITTED OR TRANSMITTED IN COMPLIANCE WITH RULE 17.1(a) OR (b)

２０００年　６月２９日

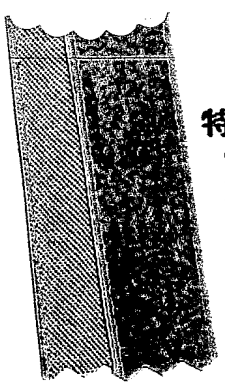

特許庁長官
Commissioner,
Patent Office

近藤隆彦

出証番号　出証特２０００－３０５２００６

【書類名】　特許願

【整理番号】　J0074155

【提出日】　平成11年 6月 4日

【あて先】　特許庁長官　殿

【国際特許分類】　G06F 17/30

G06F 7/36

【発明の名称】　文書分類方法及び文書分類装置並びに文書分類処理プログラムを記録した記録媒体

【請求項の数】　12

【発明者】

【住所又は居所】　長野県諏訪市大和３丁目３番５号　セイコーエプソン株式会社内

【氏名】　長石　道博

【特許出願人】

【識別番号】　000002369

【氏名又は名称】　セイコーエプソン株式会社

【代表者】　安川　英昭

【代理人】

【識別番号】　100093388

【弁理士】

【氏名又は名称】　鈴木　喜三郎

【連絡先】　０２６６－５２－３１３９

【選任した代理人】

【識別番号】　100095728

【弁理士】

【氏名又は名称】　上柳　雅誉

【選任した代理人】

【識別番号】　100107261

【弁理士】

【氏名又は名称】　須澤　修

【手数料の表示】

【予納台帳番号】　013044

【納付金額】　21,000円

【提出物件の目録】

【物件名】　明細書　1

【物件名】　図面　1

【物件名】　要約書　1

【包括委任状番号】　9711684

【プルーフの要否】　要

【書類名】　明細書

【発明の名称】　文書分類方法及び文書分類装置並びに文書分類処理プログラムを記録した記録媒体

【特許請求の範囲】

【請求項１】　複数の文書を意味的に共通性を有する複数のクラスタに分類する文書分類方法において、

前記複数の文書を意味的に共通性を有する複数のクラスタに分類したのちに、その複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ処理を行い、

このクラスタマージ処理によって得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成し、その表示内容をユーザに提示すべき分類結果に含めて出力することを特徴とする文書分類方法。

【請求項２】　前記クラスタマージ処理内容がわかるような表示内容とは、前記統合されたそれぞれのクラスタ間の関連性の高さに基づき、当該それぞれのクラスタのクラスタ名の表示の仕方を変えた表示内容であって、それぞれのクラスタ名の表示の仕方は、前記クラスタ間の関連性の高さが予め設定された値より大きい場合には、それぞれのクラスタ名をＡＮＤ形式の表記の仕方で表示させ、前記クラスタ間の関連性の高さが予め設定された値未満である場合には、それぞれのクラスタ名をＯＲ形式の表記の仕方で表示させることを特徴とする請求項１記載の文書分類方法。

【請求項３】　前記ＡＮＤ形式の表記の仕方は、それぞれのクラスタ対応のクラスタ名を横方向に並べて連続的に表記するか、それぞれのクラスタ対応のクラスタ名ごとに改行して縦に並べて表記するかのいずれかで行い、前記ＯＲ形式の表記の仕方は、それぞれのクラスタ対応のクラスタ名の間に区切り記号を挿入して表記することを特徴とする請求項２記載の文書分類方法。

【請求項４】　あるクラスタの中に包含されるようなクラスタが存在する場合には、包含されるクラスタ名を、包含するクラスタのクラスタ名に対し括弧書きの表記の仕方で表示することを特徴とする請求項２または３に記載の文書分類方法。

【請求項５】　複数の文書を意味的に共通性を有する複数のクラスタに分類する文書分類装置において、

前記複数の文書を意味的に共通性を有する複数のクラスタに分類するクラスタリング部と、

このクラスタリング部によって得られた複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ部と、

このクラスタマージ部によってクラスタマージ処理されて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成するクラスタマージ内容生成部と、

その表示内容をユーザに提示すべき分類結果に含めて出力する分類結果出力手段と、

を有したことを特徴とする文書分類装置。

【請求項６】　前記前記クラスタマージ処理内容生成手段が生成するクラスタマージ処理内容がわかるような表示内容は、前記統合されたそれぞれのクラスタ間の関連性の高さに基づき、当該それぞれのクラスタのクラスタ名の表示の仕方を変えた表示であって、それぞれのクラスタ名の表示の仕方は、前記クラスタ間の関連性の高さが予め設定された値より大きい場合には、それぞれのクラスタ名をＡＮＤ形式の表記の仕方で表示させ、前記クラスタ間の関連性の高さが予め設定された値未満である場合には、それぞれのクラスタ名をＯＲ形式の表記の仕方で表示させることを特徴とする請求項５記載の文書分類装置。

【請求項７】　前記ＡＮＤ形式の表記の仕方は、それぞれのクラスタ対応のクラスタ名を横方向に並べて連続的に表記するか、それぞれのクラスタ対応のクラスタ名ごとに改行して縦に並べて表記するかのいずれかで行い、前記ＯＲ形式

の表記の仕方は、それぞれのクラスタ対応のクラスタ名の間に区切り記号を挿入して表記することを特徴とする請求項６記載の文書分類装置。

【請求項８】　あるクラスタの中に包含されるようなクラスタが存在する場合には、包含されるクラスタ名を、包含するクラスタのクラスタ名に対し括弧書きの表記の仕方で表示することを特徴とする請求項６または７に記載の文書分類装置。

【請求項９】　複数の文書を意味的に共通性を有する複数のクラスタに分類して出力する文書分類処理プログラムを記録した記録媒体であって、その処理プログラムは、

複数の文書を意味的に共通性を有する複数のクラスタに分類する手順と、

その複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ処理を行う手順と、

クラスタマージ処理されて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成する手順と、

その表示内容をユーザに提示すべき分類結果に含めて出力する手順と、

を含むことを特徴とする文書分類処理プログラムを記録した記録媒体。

【請求項１０】　前記クラスタマージ処理内容がわかるような表示内容とは、前記統合されたそれぞれのクラスタ間の関連性の高さに基づき、当該それぞれのクラスタのクラスタ名の表示の仕方を変えた表示内容であって、それぞれのクラスタ名の表示の仕方は、前記クラスタ間の関連性の高さが予め設定された値より大きい場合には、それぞれのクラスタ名をＡＮＤ形式の表記の仕方で表示させ、前記クラスタ間の関連性の高さが予め設定された値未満である場合には、それぞれのクラスタ名をＯＲ形式の表記の仕方で表示させることを特徴とする請求項９記載の文書分類処理プログラムを記録した記録媒体。

【請求項１１】　前記ＡＮＤ形式の表記の仕方は、それぞれのクラスタ対応のクラスタ名を横方向に並べて連続的に表記するか、それぞれのクラスタ対応のクラスタ名ごとに改行して縦に並べて表記するかのいずれかで行い、前記ＯＲ形

式の表記の仕方は、それぞれのクラスタ対応のクラスタ名の間に区切り記号を挿入して表記することを特徴とする請求項１０記載の文書分類処理プログラムを記録した記録媒体。

【請求項１２】　あるクラスタの中に包含されるようなクラスタが存在する場合には、包含されるクラスタ名を、包含するクラスタのクラスタ名に対し括弧書きの表記の仕方で表示することを特徴とする請求項１０または１１に記載の文書分類処理プログラムを記録した記録媒体。

【発明の詳細な説明】

【０００１】

【発明の属する技術分野】

本発明は多数の文書を意味的に共通性を有する複数のクラスタに分類する文書分類方法および文書分類装置並びに文書分類処理プログラムを記録した記録媒体に関する。

【０００２】

【従来の技術】

多数の文書を意味的なまとまりごとの複数のクラスタに分類する際、それぞれの文書から特徴要素を抽出し、その特徴要素に基づいて分類することが行われている。その分類手法として、それぞれの文書全体（表題や本文など１つの文書を構成する文書内容全体）を特徴要素の抽出対象とし、それぞれの文書全体から特徴要素を抽出し、抽出された特徴要素に基づいて複数のクラスタに分類する文書分類方法がある。

【０００３】

この文書全体を特徴要素抽出の対象として分類を行うと、文書の形態素解析や、特徴抽出処理が非常に繁雑であり、ＣＰＵがその処理を行う場合、ＣＰＵに対する負荷を大きいものとしている。また、一般に、文書はその文書の主旨とは直接関係のない記述を多く含んでいるのが普通である。したがって、文書全体を特徴要素抽出の対象とすると、それによって分類されたクラスタは情報の分類という観点から見たとき、あまり意味のない分類となることも多い。つまり、ノイズクラスタが多数生成されてしまうということにもなる。

【０００４】

このような問題点を解決する手法として、それぞれの文書の主旨を適切に表す部分としてそれぞれの文書の表題部（タイトル）を検出して、その表題部から特徴要素を抽出して、抽出された特徴要素に基づいて文書を分類する手法がある。この手法は、文書の主旨を適切に反映した文書分類を可能とすることができるものとして期待される。

【０００５】

このように、従来から文書を幾つかのクラスタに分類する手法は幾つか考えられている。

【０００６】

【発明が解決しようとする課題】

しかしながら、上述した適切な分類がなされる手法である文書の表題部から抽出された特徴要素に基づいて文書を分類する手法を用いたとしても、それによって得られる分類結果は、クラスタの数が多くなりすぎることもあり、ユーザ側から見たときに、決して適切な分類が行われたとは思えない場合もでてくる。たとえば、分類されて得られる多数のクラスタを比較した場合、それぞれのクラスタに共通した文書が数多く含まれる場合もある。このような場合、ユーザは提示された多数のクラスタについて、結局は、自分で整理し、その中から自分の本当に欲しい情報を探すというような面倒な処理を行うことになる。

【０００７】

これに対処する方法として、分類されて得られた多数のクラスタに対し、それぞれのクラスタ間で内容の関連性を判断し、関連性のあるクラスタ同志を統合して新たなクラスタを生成するクラスタマージ技術も提案されている。

【０００８】

このようなクラスタマージ処理を行うと、最初のクラスタリング処理によって、多数のクラスタが生成されたとしても、内容の関連性の高いクラスタ同志が統合されるので、簡潔化されたクラスタリング結果をユーザに提示することができ、ユーザは自分の欲しい情報を効率よく探すことができるようになる。

【０００９】

しかし、クラスタマージ後のクラスタをユーザに提示する際、単に、クラスタマージ処理結果が提示されたとすると、ユーザ側からみたとき、どのようなクラスタマージ処理がなされて統合されたのかといったクラスタマージ処理内容、すなわち、そのクラスタマージによって得られた新たなクラスタは、もともとどのクラスタとどのクラスタがどの程度の関連性があるから統合されたのかといった内容がわかりにくくなることがある。

【００１０】

そこで、本発明は、内容に関連性のある複数のクラスタを統合するクラスタマージ処理がなされたあと、そのクラスタマージ処理されて得られたら新たなクラスタを表示する際、その新たなクラスタは、どのクラスタとどのクラスタがどの程度の関連性があるから統合されたのかといったクラスタマージ処理内容がわかるように表示することを目的としている。

【００１１】

【課題を解決するための手段】

前述の目的を達成するために、本発明の文書分類方法は、複数の文書を意味的に共通性を有する複数のクラスタに分類する文書分類方法において、前記複数の文書を意味的に共通性を有する複数のクラスタに分類したのちに、その複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ処理を行い、このクラスタマージ処理によって得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成し、その表示内容をユーザに提示すべき分類結果に含めて出力するようにしている。

【００１２】

また、本発明の文書分類装置は、複数の文書を意味的に共通性を有する複数のクラスタに分類する文書分類装置において、前記複数の文書を意味的に共通性を有する複数のクラスタに分類するクラスタリング部と、このクラスタリング部に

よって得られた複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ部と、このクラスタマージ部によってクラスタマージ処理されて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成するクラスタマージ内容生成部と、その表示内容をユーザに提示すべき分類結果に含めて出力する分類結果出力手段とを有した構成としている。

【００１３】

さらに、本発明の文書分類処理プログラムを記録した記録媒体は、複数の文書を意味的に共通性を有する複数のクラスタに分類して出力する文書分類処理プログラムを記録した記録媒体であって、その処理プログラムは、複数の文書を意味的に共通性を有する複数のクラスタに分類する手順と、その複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ処理を行う手順と、クラスタマージ処理されて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成する手順と、その表示内容をユーザに提示すべき分類結果に含めて出力する手順とを含むようにしている。

【００１４】

これら各発明において、前記クラスタマージ処理内容がわかるような表示内容とは、前記統合されたそれぞれのクラスタ間の関連性の高さに基づき、当該それぞれのクラスタのクラスタ名の表示の仕方を変えた表示内容であって、それぞれのクラスタ名の表示の仕方は、前記クラスタ間の関連性の高さが予め設定された値より大きい場合には、それぞれのクラスタ名をＡＮＤ形式の表記の仕方で表示させ、前記クラスタ間の関連性の高さが予め設定された値未満である場合には、それぞれのクラスタ名をＯＲ形式の表記の仕方で表示させるようにしている。

【００１５】

そして、前記ＡＮＤ形式の表記の仕方は、それぞれのクラスタ対応のクラスタ名を横方向に並べて連続的に表記するか、それぞれのクラスタ対応のクラスタ名ごとに改行して縦に並べて表記するかのいずれかで行い、前記ＯＲ形式の表記の仕方は、それぞれのクラスタ対応のクラスタ名の間に区切り記号を挿入して表記するようにしている。

【００１６】

さらに、あるクラスタの中に包含されるようなクラスタが存在する場合には、包含されるクラスタ名を、包含するクラスタのクラスタ名に対し括弧書きの表記の仕方で表示することも可能としている。

【００１７】

このように本発明は、クラスタマージされて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成し、それを表示するようにしている。

【００１８】

これによって、ユーザは、クラスタマージされる前のクラスタの様子、すなわち、どのクラスタとどのクラスタがどの程度の関連性を有して統合されたのかといったことを表示内容を見るだけで知ることができる。そして、どのような関連性を有しているかを示す表示の仕方としては、クラスタマージ処理されて得られた新たなクラスタに含まれるクラスタ間の関連性の高さに基づき、クラスタマージ処理されたそれぞれのクラスタのクラスタ名の表示の仕方を変えるようにしている。

【００１９】

そのクラスタ名の表示の仕方は、具体的には、前記クラスタ間の関連性の高さが予め設定された値より大きい場合には、それぞれのクラスタ名をＡＮＤ形式の表記の仕方で表示させ、前記クラスタ間の関連性の高さを表す値が予め設定された値未満である場合には、それぞれのクラスタ名をＯＲ形式の表記の仕方で表示させるようにしている。たとえば、関連性の高さがきわめて高い場合には、それ

ぞれのクラスタ名を横一列に連続的に表示したり、それぞれのクラスタ名を１つづつ縦に並べて表示し、関連性の高さがそれほどでもない場合には、それぞれのクラスタ名の間に区切り記号を挿入するなどして表示する。ユーザはこのような表示を見ることで、統合される前のそれぞれのクラスタがどのようなクラスタであって、それぞれのクラスタ同志の関連性がどの程度であるかなどを知ることができる。

【００２０】

また、あるクラスタの中に包含されるようなクラスタが存在する場合には、包含されるクラスタ名を、包含するクラスタのクラスタ名に対し括弧書きの表記の仕方で表示することも可能であり、包含関係であることを繁雑なイメージを使わないでもわかりやすく表示できる。

【００２１】

【発明の実施の形態】

以下、本発明の実施の形態について説明する。なお、この実施の形態で説明する内容は、本発明の文書分類方法および文書分類装置についての説明であるとともに、本発明の文書分類処理プログラムを記録した記録媒体における文書分類処理プログラムの具体的な処理内容をも含むものである。

【００２２】

また、この実施の形態では、文書分類の手法として、前述したように、それぞれの文書の表題部（タイトル）を検出して、その表題部から特徴要素を抽出して、抽出された特徴要素に基づいて文書を分類する手法を用いるものとする。

【００２３】

図１は本発明を実現するための装置構成を示すもので、大きく分けると、それぞれの文書を意味的に共通性を有する複数のクラスタに分類するクラスタリング部１と、このクラスタリング部１によって得られた複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ部２と、このクラスタマージ部２によってクラスタマージ処理されて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内

容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成するクラスタマージ処理内容生成部３と、その表示内容をユーザに提示すべき分類結果に含めて出力する分類結果出力部４とを有した構成となっている。

【００２４】

クラスタリング部１は、文書記憶部１１、文解析部１２、特徴要素抽出部１３、特徴テーブル作成部１４、文書分類部１５、分類結果記憶部１６を有している。

【００２５】

文書記憶部１１はこの場合、多数の文書データをデータベースとして持つものである。ここでは、たとえば、図２に示すような文書群を分類する場合を説明する。図２に示される文書群は、それぞれが独立した文書Ｄ１，Ｄ２，・・・，Ｄ７を有し、これらの文書Ｄ１，Ｄ２，・・・，Ｄ７は表題部Ｔ１，Ｔ２，・・・，Ｔ７と、それに対する本文Ａ１，Ａ２，・・・，Ａ７を持っているものとする。

【００２６】

文解析部１２は文書記憶部１１に記憶されている文書を文解析し、それぞれの文書の表題部を検出する。この文解析部１２が行う表題部の検出は、具体的には次のようにして行う。

【００２７】

まず、第１の方法として、文書構造様式によって表題と規定される部分があればその部分を表題部とする。また、第２の方法として、文書構造様式によって、標準より大きな文字で表示する指定がなされている部分があれば、その部分を表題部とする。また、第３の方法として、定められた数の文または単語を文書先頭より抽出し、その抽出した部分を表題部とする。さらには、これら第１、第２、第３の方法を順次行い、第１の方法を行ったとき、表題と規定されている部分があればその部分を表題部とし、表題と規定される部分が存在しなければ、第２の方法を行い、標準より大きな文字で表示する指定がなされている部分があれば、その部分を表題部とし、標準より大きな文字で表示する指定がなされていなけれ

ば、第３の方法を行って表題部を検出する。

【００２８】

特徴要素抽出部１３は、文解析部２で検出されたそれぞれの文書の表題部の中から特徴要素を抽出する。

【００２９】

特徴テーブル作成手段１４は、前記表題部から抽出された特徴要素とそれぞれの文書との関係を示す特徴テーブルを作成する。なお、この特徴テーブルの具体的な内容については後述する。

【００３０】

文書分類部１５は、前述の特徴テーブルの内容を参照し、文書Ｄ１，Ｄ２，・・・，Ｄ７を意味的に共通性のある複数のクラスタに分類する。つまり、文書Ｄ１，Ｄ２，・・・，Ｄ７の表題部に存在する特徴要素に基づいて、共通する特徴要素を持つ処理対象文書を１つのまとまりとし、そのまとまりを１つのクラスタとする。なお、この文書分類部１５は同義特徴辞書（図示せず）を有し、共通する特徴要素を持つ処理対象文書を１つのまとまりとする処理を行う際、共通する特徴要素であるか否かの判断を、その同義語辞書を用い同義語が有るか否かにより行い、同義語が存在する場合にはそれを同じクラスタとする処理を行うことも可能である。

【００３１】

分類結果記憶部１６は、文書分類部１５によって分類された内容を記憶する。

【００３２】

クラスタマージ部２は、複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合する処理を行うものであるが、その具体的な処理については後述する。

【００３３】

クラスタマージ処理内容生成部３は、前記クラスタマージ部２で判断されたクラスタ間の関連性の高さを示す値（後述する）を用い、その値を予め設定されたしきい値（後述する）と比較して関連性の高さを判断する関連性判断部３１と、

この関連性判断部３１によるクラスタ間の関連性の高さに基づいて、どのようなクラスタがどのような関連性を有して統合されたかがわかるように、それぞれのクラスタ名の表示の仕方を決めるクラスタ名表示内容決定部３２とを有し、その具体的な処理内容については後述する。

【００３４】

また、分類結果出力部４は、出力制御部４１と表示部４２を有し、本発明による文書分類結果を出力する。

【００３５】

このような構成において、本発明の文書分類処理について説明する。本発明が行う概略的な文書分類処理は、図３のフローチャートに示すように、処理対象となる多数の文書を意味的に共通性を有する複数のクラスタに分類し（ステップＳ１）、これにより分類された複数のクラスタ間で各々のクラスタに含まれる文書に基づいて、それぞれのクラスタ間の関連性を判断する（ステップＳ２）。そして、一定以上の関連性を有する少なくとも２つのクラスタを統合する（ステップＳ３）。その後、クラスタマージされて得られた新たなクラスタは、どのようなクラスタがどのような関連性を有して統合されたかがわかるようなクラスタマージ内容を生成する。具体的には、クラスタマージされたクラスタ間の関連性の高さを判定し（ステップＳ４）、その関連性の高さに基づいて、統合される前の個々のクラスタに関する情報がわかるような表示内容、すなわち、クラスタマージによって得られた新たなクラスタは、どのクラスタとどのクラスタがどの程度の関連性を有して統合されたのかがわかるような表示内容を生成する（ステップＳ５）。以下、具体例を参照して詳細に説明する。

【００３６】

ここでは、図２で示した文書Ｄ１，Ｄ２，・・・，Ｄ７を分類する例について説明する。この実施の形態では、それぞれぞれの文書の表題部から特徴要素を抽出し、その抽出された特徴要素に基づいてクラスタリング処理を行い、かつ、そのクラスタリング処理された結果についてクラスタマージ処理を行う。まず始めに、表題部から特徴要素を抽出し、その抽出された特徴要素に基づいて行われるクラスタリング処理（クラスタリング部１が行う処理）について説明する。

【００３７】

これらの文書Ｄ１，Ｄ２，・・・，Ｄ７は、文解析部１２にて表題部が検出される。たとえば、文書Ｄ１については表題部Ｔ１が検出され、文書Ｄ２については表題部Ｔ２が検出され、文書Ｄ３については表題部Ｔ３が検出されるというように、それぞれの文書Ｄ１，Ｄ２，・・・，Ｄ７の表題部Ｔ１，Ｔ２，・・・，Ｔ７が検出される。

【００３８】

そして、特徴要素抽出部１３によって、それぞれの表題部に存在する特徴要素が抽出されたのち、特徴テーブル作成部１４により、それぞれの特徴要素とその特徴要素を表題部に含む文書との関係を示す特徴テーブルが作成される。この特徴テーブルの例を図４に示す。なお、ここでは、文書数が３つ以上取り出される特徴要素とその特徴要素を含む文書との関係を示し、特徴テーブル内に示される数値は、その特徴要素が各文書の表題部に幾つ含まれるているかの数を示している。たとえば、「用紙」という特徴要素は、文書Ｄ１，Ｄ４，Ｄ６，Ｄ７のそれぞれの表題部に、それぞれ１個ずつ含まれていることを示している。

【００３９】

図４の特徴テーブルからもわかるように、表題部に「用紙」という特徴要素を含む文書は、文書Ｄ１，Ｄ４，Ｄ６，Ｄ７であり、また、表題部に「カセット」という特徴要素を含む文書は、文書Ｄ１，Ｄ４，Ｄ７であり、さらに、表題部に「増設」という特徴要素を含む文書は、文書Ｄ２，Ｄ３，Ｄ５，Ｄ７である。なお、図２において、これら各特徴要素部分にはアンダーラインが施されている。

【００４０】

そして、文書分類部１５はこのような特徴テーブルを参照して、それぞれの特徴要素ごとの文書クラスタ分けを行う。その分類結果を図５に示す。なお、このようなクラスタに分類する際、前述したように、共通する特徴要素であるか否かの判断を、同義語辞書を用い同義語が有るか否かによっても行い、同義語が存在する場合にはそれを同じ文書クラスタとする処理を行うことも可能である。たとえば、「用紙」と「印刷紙」の両方が特徴要素として抽出されたとすれば、これらの特徴要素を表題部に含む文書は同じクラスタとするなどという処理を行う。

【００４１】

このような分類結果は分類結果記憶部１６に格納される。図５に示される分類結果において、たとえば、「用紙」で分類されたクラスタ（文書Ｄ１，Ｄ４，Ｄ６，Ｄ７が含まれる）について見れば、図２の文書内容からもわかるように、文書Ｄ１は用紙カセットについての内容であり、文書Ｄ４は用紙設定についての内容であり、文書Ｄ６は印刷された後の用紙の汚れについての内容であり、文書Ｄ７は用紙カセットの増設についての内容である。

【００４２】

このように、これらの文書Ｄ１，Ｄ４，Ｄ６，Ｄ７はどれも用紙に関する内容であり、１つのクラスタとして分類されて何等問題のないものとなり、その分類結果は適切であるといえる。

【００４３】

また、「カセット」で分類されたクラスタ（文書Ｄ１，Ｄ４，Ｄ７が含まれる）について見れば、図２の文書内容からもわかるように、文書Ｄ１は用紙カセットについての内容であり、文書Ｄ４は用紙設定についての内容であり、文書Ｄ７は用紙カセットの増設についての内容である。

【００４４】

このように、これらの文書Ｄ１，Ｄ４，Ｄ６，Ｄ７にはどれも用紙をセットすることに関する内容が含まれており、１つのクラスタとして分類されて何等問題のないものとなり、その分類結果は適切であるといえる。

【００４５】

また、「増設」で分類されたクラスタ（文書Ｄ２，Ｄ３，Ｄ５，Ｄ７が含まれる）について見れば、図２の文書内容からもわかるように、文書Ｄ２はメモリの増設についての内容であり、文書Ｄ３はインタフェースカードの増設についての内容であり、文書Ｄ５はハードディスクの増設についての内容であり、文書Ｄ７は用紙カセットの増設についての内容である。

【００４６】

このように、これらの文書Ｄ２，Ｄ３，Ｄ５，Ｄ７はどれも何かを増設する場合についての内容であり、１つのクラスタとして分類されて何等問題のないもの

となり、その分類結果は適切であるといえる。

【００４７】

このような適切な分類が行える理由としては、それぞれの文書の表題部から特徴要素を抽出し、その特徴要素に基づいて文書を分類しているからである。つまり、文書の表題部は、その文書の作成者がその文書の主旨を表す内容を表現していることが多い。したがって、文書の表題部に含まれる特徴要素を用いて分類を行うことにより、分類結果が散漫になることが少なく、また、ノイズクラスタが生成される率も少なくすることができる。また、各文書の表題部は、その文書の作成者がその文書の主旨を表す内容を表現していることから、文書の制作者側の視点による分類が得られる。

【００４８】

そして、分類が行われた後、ユーザによって、たとえば、「用紙」についてのクラスタの選択指示が出されたとすると、そのクラスタに属する文書Ｄ１，Ｄ４，Ｄ６，Ｄ７が文書記憶部１１から読み出されて表示部３２に表示される。なお、このときの表示内容としては、前述したように、文書番号や文書名のみでもよく、さらには、その文書内容を表示させるようにしてもよい。

【００４９】

ところで、本発明は以上のようにクラスタリング処理した結果について、さらに、クラスタマージ部２によってクラスタマージ処理を行う。

【００５０】

すなわち、図５に示す分類結果において、特徴要素である「用紙」と「カセット」について見ると、「用紙」のクラスタには文書Ｄ１，Ｄ４，Ｄ６，Ｄ７が含まれ、「カセット」のクラスタには文書Ｄ１，Ｄ４，Ｄ７に存在することがわかる。

【００５１】

このように、「用紙」のクラスタと「カセット」のクラスタには、共に文書Ｄ１，Ｄ４，Ｄ７が共通して存在している。これは、「用紙」という特徴要素と「カセット」という特徴要素は相互に関連した状態で用いられることが多いことを意味している。たとえば、文書Ｄ１，Ｄ４，Ｄ７の表題部または本文のなかに「

用紙カセット」という用語が用いられている。つまり、これらの文書Ｄ１，Ｄ４，Ｄ７は共通性の高い文書であり、これら文書Ｄ１，Ｄ４，Ｄ７は同じクラスタに分類した方がより好ましいと考えられる。

【００５２】

これを実現するために、特徴要素に基づいてクラスタリングしたあと、そのクラスタリング結果に対しクラスタマージ処理を施す。

【００５３】

このクラスタマージ処理について以下に説明する。まず始めに、図５の分類結果とは関係なく一般的な例について図６を参照しながら説明する。

【００５４】

今、２つのクラスタＣ１，Ｃ２があるとする。クラスタＣ１として５個の文書Ｄ１，Ｄ２，Ｄ３，Ｄ４，Ｄ８が抽出され、クラスタＣ２には６個の文書Ｄ３，Ｄ４，Ｄ５，Ｄ６，Ｄ７，Ｄ８が抽出されたとする。

【００５５】

ここで、２つのクラスタＣ１，Ｃ２に共通している文書は、文書Ｄ３，Ｄ４，Ｄ８である。この実施の形態では、クラスタマージ処理対象となる複数のクラスタに含まれる複数の文書のうち、それぞれのクラスタに共通して含まれる文書数を基に、それぞれのクラスタ間の関連性を判断してクラスタマージ処理を行う。

【００５６】

具体的には、複数のクラスタとして、ある２つのクラスタに共通している文書数が２つのクラスタに存在する合計の文書数に対しどのくらいの割合かを計算し、その計算結果が予め定めたしきい値以上かどうかによってマージするか否かを決める。

【００５７】

たとえば、この場合、２つのクラスタＣ１，Ｃ２に存在する文書数の合計は１１個であり、両者に共通する文書数は３個である。これらから合計の文書数に占める共通する文書数の割合（％）を計算し、その結果からマージするか否かを決定する。この割合（％）を求める際、合計の文書数で共通する文書数を単純に割り算してそれに１００を掛けて求めてもよいが、共通する文書数に任意に設定さ

れる係数を掛け算したものを合計の文書数で割り算してそれに１００を掛けて求めるようにしてもよい。

【００５８】

一例として、クラスタＣ１に存在する文書数をα１、クラスタＣ２に存在する文書数をα２とし、両者に共通する文書数をβとした場合、たとえばβに係数としてたとえば２を掛けて、２β／（α１＋α２）×１００を計算し、その値（％）が予め設定されたしきい値ＴＨ（％）と比較して、上式による計算結果がしきい値ＴＨ以上であればマージするというようなことを行う。図６で示した例について考えれば、２βは２×３＝６個、α１＋α２は５＋６＝１１個であるので、この場合、約５５％と求められる。ここで、しきい値ＴＨが仮に７０％と設定されているとすれば、計算結果（５５％）はしきい値ＴＨ（７０％）より小さいので、クラスタＣ１とクラスタＣ２はマージしないとする。なお、係数は任意に設定されるもので、計算結果で得られる数値（％）がしきい値と比較し易いような値となるように適当に設定されるものであり、この場合は係数を２としたが、係数を１としても特に問題はない。

【００５９】

ここで、図５で示した分類結果を例にして説明すれば、図５の場合、「用紙」のクラスタには文書Ｄ１，Ｄ４，Ｄ６，Ｄ７の４つの文書が存在し、「カセット」のクラスタには文書Ｄ１，Ｄ４，Ｄ７の３つの文書が存在する。そして、２つのクラスタに共通する文書は文書Ｄ１，Ｄ４，Ｄ７の３つの文書であり、これを合計の文書数に対する割合（％）で考える。

【００６０】

これを前述した計算式によって計算する。図５の分類結果の場合、合計の文書数（α１＋α２）は、４＋３＝７となり、共通の文書数は３で２βは６となる。したがって、この場合、約８６％という高い値が得られる。これは、設定されたしきい値（ここでは７０％としている）よりも高いので、この「用紙」のクラスタと「カセット」のクラスタはマージして１つのクラスタとするということになる。

【００６１】

同様に考えて、図５の「用紙」のクラスタと「増設」のクラスタとをマージするか否か、「カセット」のクラスタと「増設」のクラスタとをマージするか否かについて判断する。

【００６２】

まず、「用紙」のクラスタと「増設」のクラスタについては、「用紙」のクラスタには文書Ｄ１，Ｄ４，Ｄ６，Ｄ７の４つの文書が存在し、「増設」のクラスタには文書Ｄ２，Ｄ３，Ｄ５，Ｄ７の４つの文書が存在する。そして、２つのクラスタに共通する文書は文書Ｄ７のみであり、これを上式を用いて計算すると、この場合、２５％という結果が得られ、これは、しきい値（７０％）よりも低い値であるので、この場合は、両者はマージしないとする。

【００６３】

また、「カセット」のクラスタと「増設」のクラスタについては、「カセット」のクラスタには文書Ｄ１，Ｄ４，Ｄ７の３つの文書が存在し、「増設」のクラスタには文書Ｄ２，Ｄ３，Ｄ５，Ｄ７の４つの文書が存在する。そして、２つのクラスタに共通する文書は文書Ｄ７のみであり、これを上式を用いて計算すると、この場合、約２８％という結果が得られ、これは、しきい値（７０％）よりも低い値であるので、この場合は、両者はマージしないとする。

【００６４】

このようにして、それぞれのクラスタに対し２つのクラスタごとにそれぞれマージするか否かを判断する。この図５の分類結果についてマージするか否かの処理を行ったあとの分類結果（マージ処理後の分類結果という）が図７である。図７によれば、「用紙」と「カセット」が「用紙＋カセット」という１つのクラスタに分類され、そのクラスタに属する文書は文書Ｄ１，Ｄ４，Ｄ６，Ｄ７ということになる。また、「増設」についてはそのまま単独のクラスタを構成する。

【００６５】

図７に示されるクラスタマージ処理後の分類結果において、たとえば、「用紙＋カセット」で分類されたクラスタ（文書Ｄ１，Ｄ４，Ｄ６，Ｄ７が含まれる）について見れば、図２の文書内容からもわかるように、文書Ｄ１は用紙カセット

についての内容であり、文書Ｄ４は用紙設定についての内容であり、文書Ｄ６は印刷された後の用紙の汚れた場合にはどのようにするかについての内容であり、文書Ｄ７は用紙カセットの増設についての内容である。

【００６６】

このように、これらの文書Ｄ１，Ｄ４，Ｄ６，Ｄ７はどれも用紙やカセットに関する内容であり、１つのクラスタとして分類されて何等問題のないものとなり、むしろ、「用紙＋カセット」を１つのクラスタとした方がよい分類結果であるといえる。

【００６７】

このように、始めにそれぞれの文書の表題部から特徴要素を抽出し、その抽出された特徴要素に基づいてクラスタリング処理を行い、かつ、そのクラスタリング処理されて得られたそれぞれのクラスタに対し、２つづつのクラスタの組み合わせについてクラスタマージ処理を行うことによって、より適切なクラスタリングが行える。

【００６８】

また、以上のようにして２つのクラスタごとに１回目のクラスタマージ処理が終了し、図７のようなクラスタマージ処理後の分類結果が得られると、今度は、そのクラスタマージ処理後の分類結果について、２回目のクラスタマージ処理を行う。つまり、図７の１回目のクラスタマージ処理後の結果で考えた場合、「用紙＋カセット」のクラスタと「増設」のクラスタについてクラスタマージ処理を行う。この場合、「用紙＋カセット」のクラスタと「増設」のクラスタについては、「用紙＋カセット」のクラスタには文書Ｄ１，Ｄ４，Ｄ６，Ｄ７の４つの文書が存在し、「増設」のクラスタには文書Ｄ２，Ｄ３，Ｄ５，Ｄ７の４つの文書が存在する。そして、２つのクラスタに共通する文書は文書Ｄ７のみであり、これを合計の文書数に対する割合（％）で考えると、共通する文書数１に定数２を掛けたものを合計の文書数８で割り算し、それに１００を掛けると、２５％という結果が得られ、これは、しきい値（７０％）よりも低い値であるので、この場合は、両者はマージしないとする。

【００６９】

このようにして、２つのクラスタ間で１回目のクラスタマージ処理が終了した後、その１回目のクラスタマージ処理に新たな２つのクラスタ間で２回目のクラスタマージ処理を行い、その２回目のクラスタマージ処理が終了した後、その２回目のクラスタマージ処理後に新たな２つのクラスタ間で３回目のクラスタマージ処理を行うというクラスタマージ処理を順次行い、新たなクラスタが生成されなくなるまで（クラスタマージが起こらなるまで）その処理を繰り返す。

【００７０】

また、これまでの説明では、２つのクラスタ間でクラスタマージ処理を行う例について説明したが、クラスタマージ処理は３つ以上のクラスタの組み合わせについても可能である。この場合、１回のクラスタマージ処理によって３つ以上のクラスタ間でクラスタマージ処理を行い、さらに、これによって幾つかのクラスタに分類された結果についてクラスタマージが起こらなくなるまで、順次、クラスタマージ処理を行うことも可能である。なお、３つ以上のクラスタについてクラスタマージするか否かを判断する場合、前述したように、それぞれのクラスタに存在する合計の文書数に対する共通の文書数の割合（％）で考えることができる。

【００７１】

以上のようにしてクラスタマージ部２によるクラスタマージ処理が終了すると、次に、クラスタマージ処理内容生成部３がそのクラスタマージ結果に対し、クラスタマージされたクラスタ間の関連性の高さを判定し、その関連性の高さに基づいて、統合される前の個々のクラスタに関する情報がわかるような表示内容、すなわち、クラスタマージによって得られた新たなクラスタは、どのクラスタとどのクラスタがどの程度の関連性を有して統合されたのかがわかるような表示内容を生成する。以下、このクラスタマージ処理内容生成部３が行う処理について説明する。

【００７２】

この実施の形態では、クラスタマージ部２によって得られた関連性の高さとしての関連性の度合い（％）の値が、前述したしきい値ＴＨよりずっと大きい値で

あるか、しきい値ＴＨに近い値であるかによって、そのクラスタマージされたクラスタ間の関連性の高さを関連性判断部３１によって判断する。具体的には、前述のしきい値ＴＨに対し、それよりも高い値（％）のしきい値ＴＨ１を設定し、クラスタマージ部２によって得られた関連性の度合い（Ｋで表す）が、Ｋ≧ＴＨ１であれば、クラスタ同志の関連性はきわめて大きく殆ど同じ内容であると判断する。一方、クラスタマージ部２によって得られた関連性の度合いＫが、ＴＨ１＞Ｋ≧ＴＨであれば、少し似ている程度と判断する。

【００７３】

今、Ｋ≧ＴＨ１である場合、すなわち、クラスタマージされて得られた新たなクラスタに含まれる幾つかのクラスタ同志の関連性がきわめて高い場合は、次のような処理を行う。

【００７４】

これを図７の例で説明すれば、クラスタマージされた新たなクラスタの特徴要素は、「用紙＋カセット」である。この「用紙＋カセット」のクラスタは、図５に示す用紙のクラスタとカセットのクラスタをクラスタマージした結果である。このそれぞれのクラスタにクラスタ名を付けるとすれば、特徴要素が「用紙」であるクラスタを「用紙クラスタ」、特徴要素が「カセット」であるクラスタを「カセットクラスタ」といように表すことができ、それぞれのクラスタ名を以下では、単に、「用紙」、「カセット」と表記する。

【００７５】

ここで、クラスタマージ結果である「用紙＋カセット」のクラスタは、クラスタマージ部２による前述の計算によって、８６％という値が得られている。ここで、関連性判断部３１において、関連性を判断する際に設定されたしきい値ＴＨ１が８０％と設定されているとすれば、この場合、クラスタマージ部２によって得られた関連性の度合いＫは、Ｋ≧ＴＨ１であるので、用紙クラスタとカセットクラスタの関連性はきわめて大きく殆ど同じ内容であると判断できる。

【００７６】

このように、クラスタマージ部２によって得られた関連性を示す値Ｋが、Ｋ≧ＴＨ１である場合には、クラスタマージされたそれぞれのクラスタ同志の関連性

はきわめて大きく、殆ど同じ内容のクラスタであると判断でき、それぞれのクラスタの名称を、連続的に表示する。たとえば、上述の「用紙クラスタ」と「カセットクラスタ」の例では、それらのクラスタ名である「用紙」と「カセット」をくっつけて「用紙カセット」などと表記してそれを表示する。

【００７７】

これは、いわゆるＡＮＤ形式の表記の仕方であり、クラスタ名をくっつけて表記しても差し支えないような場合である。この例では、クラスタマージされて得られた新たなクラスタのクラスタ名を「用紙カセット」とすることになるが、この場合は、クラスタマージされて得られた新たなクラスタは、その新たなクラスタを構成する用紙クラスタとカセットクラスタに含まれるそれぞれの文書内容（図２参照）から見て、新たなクラスタ名を「用紙カセット」として何等差し支えないものである。

【００７８】

図８はこのような処理を行ったあとの表示例を示すもので、この図８では、クラスタマージされた新たなクラスタのクラスタ名としての「用紙カセット」と、その新たなクラスタに含まれる文書として、ここでは、図２で示されたそれぞれの文書（文書Ｄ１，Ｄ４，Ｄ６．Ｄ７）のそれぞれの表題（タイトル）名が表示されている。

【００７９】

また、このように、それぞれのクラスタ名を、連続的に表示する方法の他に、図９に示すように、それぞれのクラスタ対応のクラスタ名である「用紙」と「カセット」を、それぞれのクラスタ名ごとに改行して縦に並べて表記するようにしてもよい。

【００８０】

このように、それぞれのクラスタの名称を縦に並べると、言語的なつながりが気にならなくなり、違和感を与えない効果がある。この実施の形態で用いている「用紙」と「カセット」は、連続して「用紙カセット」としても何等問題ないが、場合によっては、違和感を持つ場合もある。たとえば、これまでの説明とは全く関係のない例として、クラスタマージされた得られた新たなクラスタに含まれ

るそれぞれのクラスタ名が、仮に、「製品」、「使用」、「概要」であったとする。このようなクラスタ名を上述のように、連続して横に一列に並べると「製品仕様概要」となる。これでも意味が全く不明というものではないが、言語的に少し違和感が生じる。このような場合、本来は、言語処理を行って、「製品仕様の概要」というようにすればよいが、そのような言語処理は複雑で時間を要する。したがって、このような場合、図９と同様に、「製品」、「使用」、「概要」を１つづつ縦に並べると違和感を与えることがなくなる。また、縦に並べることで、実際に表示したときに、横並び一列での表示に比べ、クラスタマージされたクラスタ名の数が多くても、横方向にむやみに伸びることがないので見易くなるという効果もある。

【００８１】

このように、クラスタマージ部２によって得られた関連性を示す値Ｋが、Ｋ≧ＴＨ１であって、クラスタマージされて得られた新たにクラスタに含まれるクラスタのクラスタ名をＡＮＤ形式の表記とし、クラスタ名を横一列に並べた表記の仕方で表示するか、あるいは、各クラスタ対応のクラスタ名称ごとに改行して縦に並べる表記の仕方で表示する。

【００８２】

これによって、クラスタマージされて得られた新たなクラスタは、どのようなクラスタがどのような関連性を有して統合されたかということが、そのクラスタマージされた新たなクラスタ名を見るだけでわかる。たとえば、図８や図９の例では、元のクラスタは「用紙」というクラスタと「カセット」というクラスタが統合されてできたクラスタであり、しかも、その関連性はきわめて高く同じような内容の文書を持ったクラスタであるということがわかる。

【００８３】

次に、 ＴＨ１＞Ｋ≧ＴＨである場合、すなわち、クラスタマージされて得られた新たなクラスタに含まれる幾つかのクラスタの関連性の度合いは、殆どがオーバーラップするほどでもないが同じ文書を幾つか含んでいるといった場合の処理について説明する。

【００８４】

このように、クラスタマージ部２によって得られた関連性を示す値Ｋが、ＴＨ１＞Ｋ≧ＴＨである場合には、それぞれのクラスタの名称を、いわゆるＯＲ形式の表記の仕方で行う。

【００８５】

たとえば、前述の「製品」、「使用」、「概要」の例で説明すれば、この場合、「製品」、「使用」、「概要」を連続的な表示ではなく、たとえば、「製品・使用・概要」というように、それぞれの名称間に区切りの記号を挿入して表示する。このような区切りの記号がある場合にはＯＲ的な内容であることを予めユーザに報知しておけば、それを見たユーザはそのクラスタマージされて得られた新たなクラスタには、「製品」、「使用」、「概要」といった内容を持った文書が幾つか含まれているというように理解できる。なお、このＯＲ形式の表記の仕方を行う場合、クラスタ名の間に挿入する記号は上述したような「製品・使用・概要」の例に限られるものではなく、たとえば、クラスタ名の間に「／」を挿入して「製品／使用／概要」ようにしてもよい。

【００８６】

また、クラスタマージされて得られた新たなクラスタに含まれる幾つかのクラスタの関連性に、Ｋ≧ＴＨ１と、ＴＨ１＞Ｋ≧ＴＨが混在するような場合もある。このような場合には、それぞれの関連性の度合いがわかるように、ＡＮＤ形式とＯＲ形式に分けて表記する。

【００８７】

さらに、クラスタマージされたそれぞれのクラスタ同志が包含関係にあるような場合もある。たとえば、あるクラスタが「製品」に関するクラスタであり、あるクラスタのクラスタ名が「テレビ」、あるクラスタのクラスタ名が「ラジオ」、あるクラスタのクラスタ名が「ビデオ」であって、これらのクラスタがクラスタマージされたとする。このとき、「テレビ」のクラスタ、「ラジオ」のクラスタ、「ビデオ」のクラスタが「製品」のクラスタに包含されるものであって、しかも、それぞれのクラスタ同志の関連性の度合いがＴＨ１＞Ｋ≧ＴＨの関係であったとすれば、「製品・（テレビ・ラジオ・ビデオ）」というような表記の仕方

で表示する。これは、「製品」、「テレビ」・「ラジオ」・「ビデオ」はそれぞれがＯＲ的な関係にあり、しかも、「テレビ」・「ラジオ」・「ビデオ」が括弧でくくられていることから、これら「テレビ」・「ラジオ」・「ビデオ」の各クラスタは「製品」に包含されるクラスタであることを意味している。

【００８８】

このように、クラスタマージ処理がなされて得られた新たなクラスタのクラスタ名を見るだけで、どのようなクラスタがどの程度の関連性を有して統合されたのかを容易に知ることができる。

【００８９】

なお、本発明は以上説明した実施の形態に限定されるものではなく、本発明の要旨を逸脱しない範囲で種々変形実施可能となるものである。たとえば、前述の実施の形態では、図５に示すような分類結果を得るための特徴要素を各文書の表題部から得るようにして、表題部から得られた特徴要素に基づいたクラスタリングを行う例について説明したが、本発明においては、複数の文書をクラスタリングする手法は、特に限定されるものではない。

【００９０】

複数の文書をクラスタリングする手法としては、前述の実施の形態で説明した文書の表題部から得られた特徴要素に基づいてクラスタリングを行う例の他に、たとえば、ＵＲＬアドレス（http://を取り除いた部分）、更新日時（単純な時間または最近１カ月以内の更新日時）、ファイルサイズ（webページ本文のバイトサイズなど）を用いてクラスタリングすることもできる。また、これらは、単独で用いてクラスタリングするようにしてもよく、幾つかを組み合わせてもよい。これらのどれを用いるかは、最初にメニューなどで選択項目を選ぶことで可能となる。また、選んだ項目が無い場合には、他の項目を代用する。たとえば、タイトルを選んだ場合、webページにタイトルが無い場合には、ＵＲＬアドレスを代用する。

【００９１】

そして、いずれかの方法によってクラスタリングされたのち、そのクラスタリング結果に対し、前述の実施の形態で説明したような処理、すなわち、それぞれ

のクラスタに含まれる文書の共通性を判断してそれぞれのクラスタ同志を統合するか否かを決めるという処理を施すことによってもクラスタマージを行うことができる。

【００９２】

たとえば、ＵＲＬによってクラスタリングする場合について説明すれば、あるＵＲＬ（これをＵＲＬ１とする）のクラスタと、あるＵＲＬ（これをＵＲＬ２とする）のクラスタに分類されたとし、ＵＲＬ１のクラスタには文書Ｄ１，Ｄ２，Ｄ３，Ｄ４が存在し、ＵＲＬ２のクラスタには文書Ｄ２，Ｄ３，Ｄ４，Ｄ５が存在したとする。この場合、これら２つのクラスタには、共通する文書として文書Ｄ２，Ｄ３，Ｄ４が含まれることになり、この共通する文書数と合計の文書数との関係から、ＵＲＬ１のクラスタとＵＲＬ２のクラスタを統合するか否かを決める。

【００９３】

また、クラスタマージするか否かの判断は、前述の実施の形態では、対象となるクラスタに含まれる合計の文書数で共通の文書数を割って得られる割合（％）で表し、その値が予め設定されたしきい値（％）と比較することによって行ったが、これに限られるものではなく、たとえば、共通する文書の個数を数え、その個数とそれぞれのクラスタに含まれる文書数との関係からマージするかしないかを決めるようにすることも可能である。

【００９４】

このように、個数によってクラスタマージするか否かを判断する場合、前述したしきい値は個数を用いればよい、たとえば、合計の文書数が１０個あって、共通する文書が７個以上であるときにマージするとした場合、前述のしきい値ＴＨは、たとえば７個で、ＴＨ１をたとえば９個とし、９個以上共通した文書がある場合にはＡＮＤ形式の表記の仕方での表示を行い、７個または８個の場合はＯＲ形式の表記の仕方での表示を行うというようにもできる。なお、この数値は一例であってこれに限られるものではないことは言うまでもない。これは、前述の実施の形態のなかで説明したしきい値ＴＨやＴＨ１の値についても同様のことがいえる。

【００９５】

また、前述の実施の形態では、文書Ｄ１，Ｄ２，・・・，Ｄ７は、それぞれが独立した文書であって、それぞれ独立した文書を分類する場合について説明したが、ある１つの文書を幾つかのコンテンツに分けて、それぞれのコンテンツ（ここでいうコンテンツとは文書の中の意味的なまとまりを指す）を分類する場合にも適用できる。ここで抽出されるコンテンツは、各表題部ごとに切り分けられて得られる文書の中の意味的なまとまりであるとする。

【００９６】

たとえば、図２で示した文書Ｄ１，Ｄ２，・・・，Ｄ７が集まって１つの文書が構成されていると仮定すれば、文書Ｄ１，Ｄ２，・・・，Ｄ７をそれぞれコンテンツとみなすことができる。これらをコンテンツとすれば、それぞれのコンテンツは、表題部Ｔ１，Ｔ２，・・・，Ｔ７と本文Ａ１，Ａ２，・・・，Ａ７から構成されたものとなる。

【００９７】

このように、１つの文書を複数のコンテンツに分けて考えた場合、本発明はそれぞれのコンテンツをクラスタリングし、そのクラスタリング結果をクラスタマージする場合にも同様に適応できる。

【００９８】

さらに、本発明で用いられるクラスタリング対象文書は、たとえば、汎用の検索サービスで検索された複数の文書をクラスタリング対象文書として考えることもできる。この場合、検索された多数の文書に対してクラスタリング処理を行い、そのクラスタリングされた結果についてクラスタマージ処理を行う。そして、クラスタマージされて得られた新たなクラスタに含まれるそれぞれのクラスタについて前述の実施の形態で説明したよう本発明の処理を行うことで、そのクラスタマージによって得られた新たなクラスタは、もともとどのクラスタとどのクラスタがどの程度の関連性を有して統合されたのかといった内容を容易に知ることができる。

【００９９】

また、以上説明した本発明の文書分類処理を行う処理プログラムは、フロッピ

ィディスク、光ディスク、ハードディスクなどの記録媒体に記録させておくことができ、本発明はその記録媒体をも含むものである。また、ネットワークから処理プログラムを得るようにしてもよい。

【０１００】

【発明の効果】

以上説明したように本発明によれば、クラスタマージされて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成し、それを表示するようにしている。

【０１０１】

これによって、ユーザは、クラスタマージされる前のクラスタの様子、すなわち、どのクラスタとどのクラスタがどの程度の関連性を有して統合されたのかといったことを表示内容を見るだけで知ることができる。そして、どのような関連性を有しているかを示す表示の仕方としては、クラスタマージ処理されて得られた新たなクラスタに含まれるクラスタ間の関連性の高さに基づき、クラスタマージ処理されたそれぞれのクラスタのクラスタ名の表示の仕方を変えるようにしている。

【０１０２】

そのクラスタ名の表示の仕方は、具体的には、前記クラスタ間の関連性の高さが予め設定された値より大きい場合には、それぞれのクラスタ名をＡＮＤ形式の表記の仕方で表示させ、前記クラスタ間の関連性の高さを表す値が予め設定された値未満である場合には、それぞれのクラスタ名をＯＲ形式の表記の仕方で表示させるようにしている。たとえば、関連性の高さがきわめて高い場合には、それぞれのクラスタ名を横一列に連続的に表示したり、それぞれのクラスタ名を１つづつ縦に並べて表示し、関連性の高さがそれほどでもない場合には、それぞれのクラスタ名の間に区切り記号を挿入するなどして表示する。ユーザはこのような表示を見ることで、統合される前のそれぞれのクラスタがどのようなクラスタであって、それぞれのクラスタ同志の関連性がどの程度であるかなどを知ることができる。

【０１０３】

また、あるクラスタの中に包含されるようなクラスタが存在する場合には、包含されるクラスタ名を、包含するクラスタのクラスタ名に対し括弧書きの表記の仕方で表示することも可能であり、包含関係であることを繁雑なイメージを使わないでもわかりやすく表示できる。

【０１０４】

このように本発明によれば、複数の文書を分類処理することによって生成された多数のクラスタに対し、クラスタマージ処理を施すことにより関連性の高いクラスタ同志を統合してまとめることができるので、たとえば、検索サービスなどで検索された多数の文書に対し、本発明を適用することにより、検索要求を出したユーザに対し、検索結果を簡潔化した見易いクラスタリング結果として提示することができる。これによって、ユーザは自分の欲しい情報を効率よく探すことができ、従来にはない検索サービスが実現できる。

【図面の簡単な説明】

【図１】

本発明の文書分類装置の実施の形態を説明するブロック図である。

【図２】

本発明の実施の形態を説明するための複数の文書例を示す図である。

【図３】

本発明が行う文書分類処理の処理手順を概略的に説明するフローチャートである。

【図４】

特徴要素とそれぞれの文書との関係を示す特徴テーブル内容の一例を示す図である。

【図５】

図４に示す特徴テーブルに基づいて文書を分類した分類結果を示す図である。

【図６】

２つのクラスタ間でのクラスタマージ処理を説明する図であり、それぞれのクラスタに含まれる文書例を示す図である。

【図７】

図５の分類結果についてクラスタマージ処理した結果を示す図である。

【図８】

クラスタマージされて得られた新たなクラスタに含まれるそれぞれのクラスタのクラスタ名をＡＮＤ形式（横一列に並べた場合）の表記の仕方で表示した例を示す分類結果例を示す図である。

【図９】

クラスタマージされて得られた新たなクラスタに含まれるそれぞれのクラスタのクラスタ名をＡＮＤ形式（クラスタ名を１つづつ縦に並べた場合）の表記の仕方で表示した例を示す分類結果例を示す図である。

【符号の説明】

１　クラスタリング部

２　クラスタマージ部

３　クラスタマージ処理内容生成部

４　分類結果出力部

１１　文書記憶部

１２　文解析部

１３　特徴要素抽出部

１４　特徴テーブル作成部

１５　文書分類部

１６　分類結果記憶部

３１　関連性判断部

３２　クラスタ名表示内容決定部

４１　出力制御部

４２　表示部

Ａ1，Ａ2，・・・，Ａ7　本文

Ｄ1，Ｄ2，・・・，Ｄ7　文書

Ｔ1，Ｔ2，・・・，Ｔ7　表題部

【書類名】　図面

【図１】

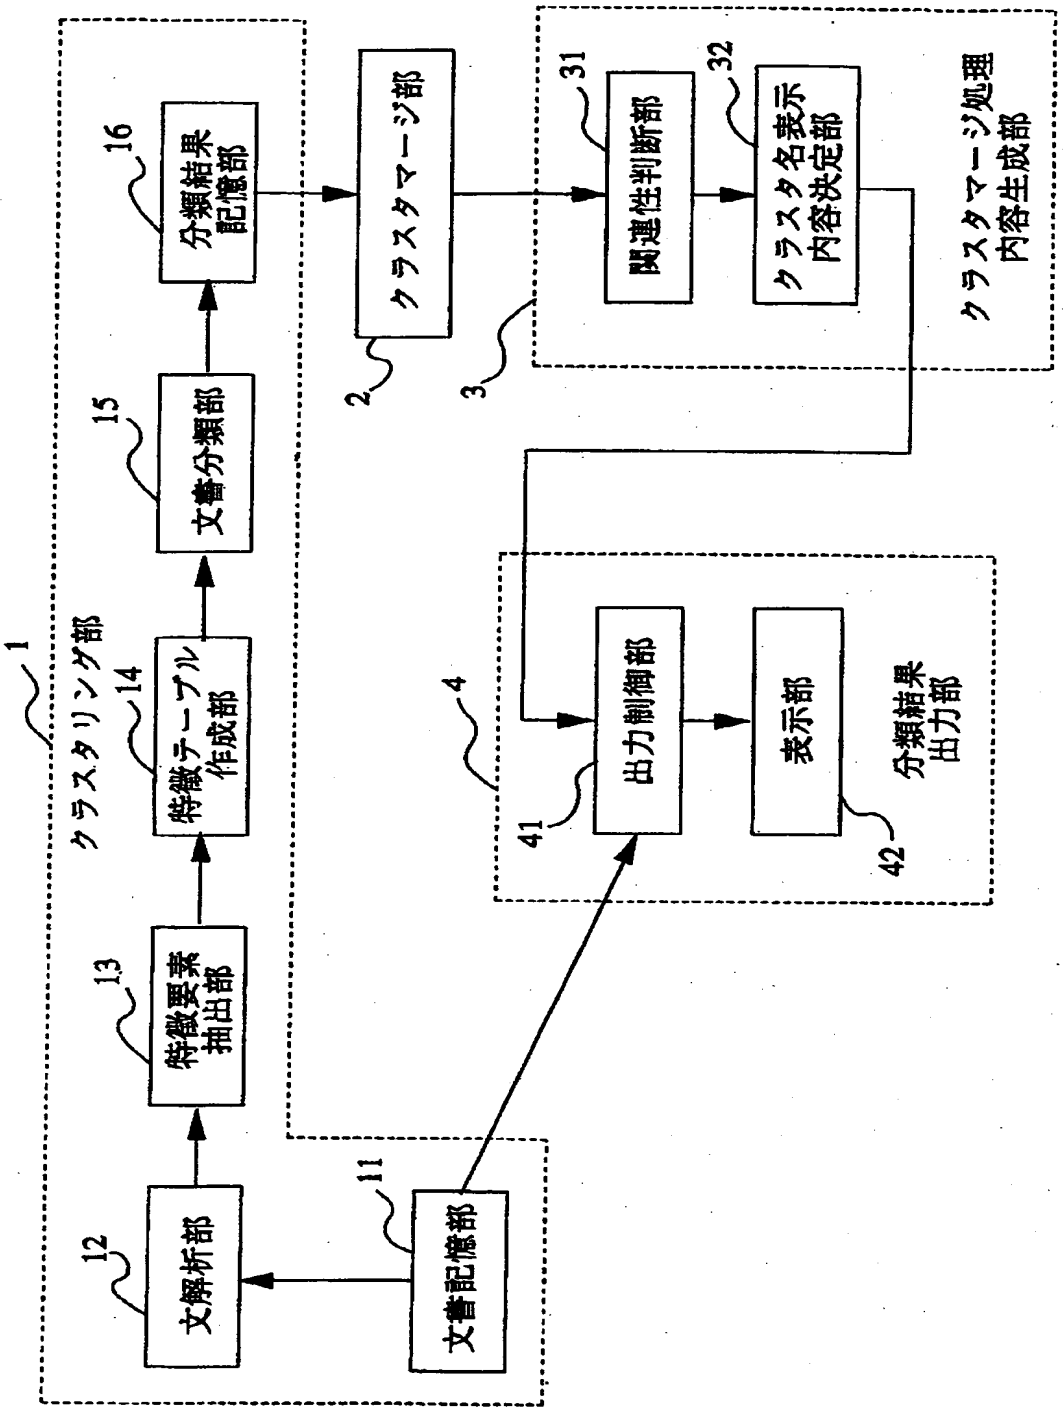
クラスタリング部
1
文書記憶部
11
文解析部
12
特徴要素抽出部
13
特徴テーブル作成部
14
文書分類部
15
分類結果記憶部
16
クラスタマージ部
2
クラスタマージ処理内容生成部
3
関連性判断部
31
クラスタ名表示内容決定部
32
分類結果出力部
4
出力制御部
41
表示部
42

【図２】

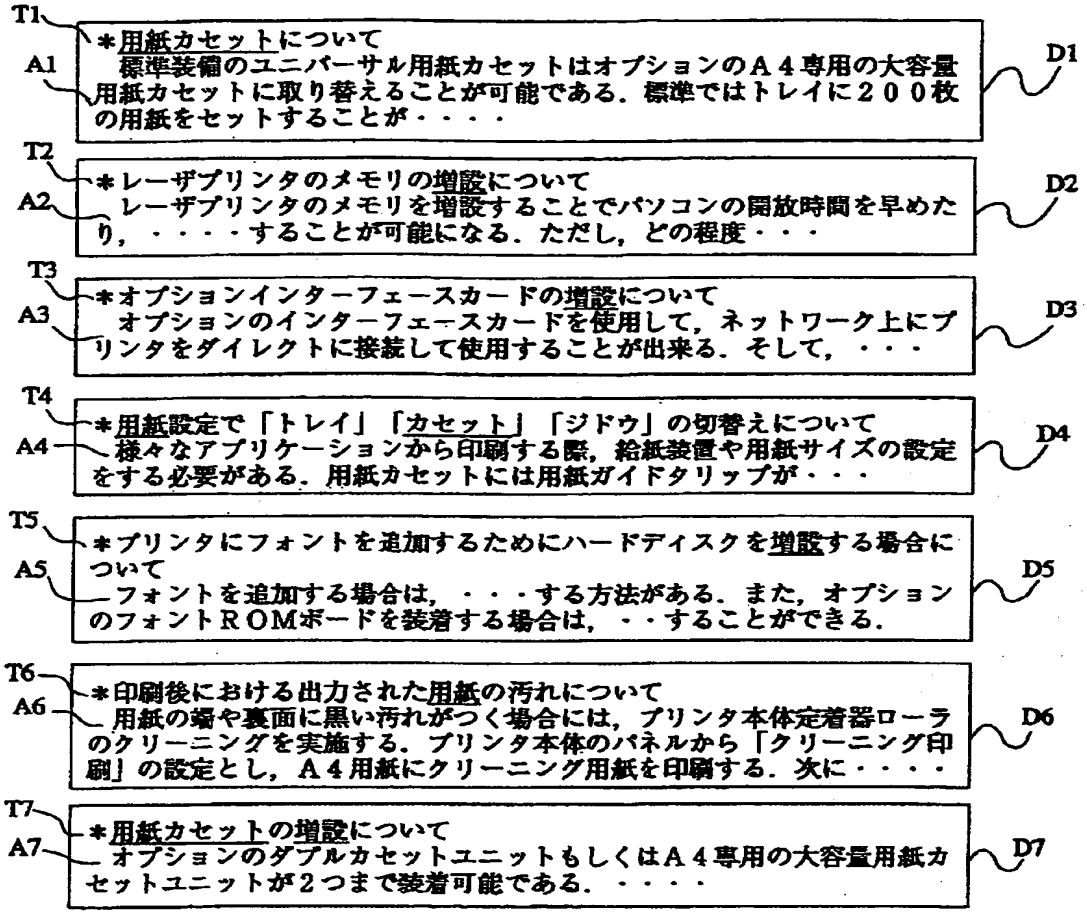
T1
＊用紙カセットについて
A1
標準装備のユニバーサル用紙カセットはオプションのＡ４専用の大容量用紙カセットに取り替えることが可能である．標準ではトレイに２００枚の用紙をセットすることが・・・・
D1
T2
＊レーザプリンタのメモリの増設について
A2
レーザプリンタのメモリを増設することでパソコンの開放時間を早めたり，・・・・することが可能になる．ただし，どの程度・・・
D2
T3
＊オプションインターフェースカードの増設について
A3
オプションのインターフェースカードを使用して，ネットワーク上にプリンタをダイレクトに接続して使用することが出来る．そして，・・・
D3
T4
＊用紙設定で「トレイ」「カセット」「ジドウ」の切替えについて
A4
様々なアプリケーションから印刷する際，給紙装置や用紙サイズの設定をする必要がある．用紙カセットには用紙ガイドタリップが・・・
D4
T5
＊プリンタにフォントを追加するためにハードディスクを増設する場合について
A5
フォントを追加する場合は，・・・する方法がある．また，オプションのフォントＲＯＭボードを装着する場合は，・・することができる．
D5
T6
＊印刷後における出力された用紙の汚れについて
A6
用紙の端や裏面に黒い汚れがつく場合には，プリンタ本体定着器ローラのクリーニングを実施する．プリンタ本体のパネルから「クリーニング印刷」の設定とし，Ａ４用紙にクリーニング用紙を印刷する．次に・・・・
D6
T7
＊用紙カセットの増設について
A7
オプションのダブルカセットユニットもしくはＡ４専用の大容量用紙カセットユニットが２つまで装着可能である．・・・・
D7

【図３】

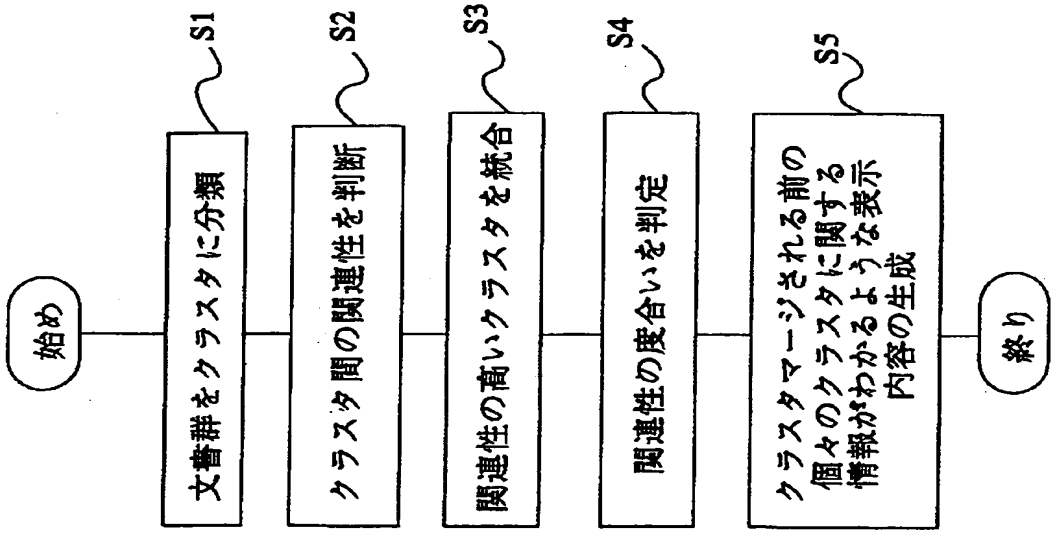
始め
S1
文書群をクラスタに分類
S2
クラスタ間の関連性を判断
S3
関連性の高いクラスタを統合
S4
関連性の度合いを判定
S5
クラスタマージされる前の
個々のクラスタに関する
情報がわかるような表示
内容の生成
終り

【図４】

特徴要素	文書D1	文書D2	文書D3	文書D4	文書D5	文書D6	文書D7
用紙	1			1		1	1
カセット	1			1			1
増設		1	1		1		1

【図５】

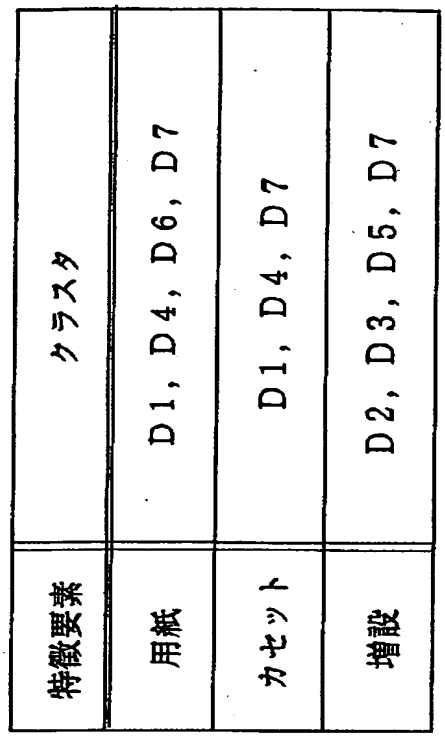

特徴要素	クラスタ
用紙	D1, D4, D6, D7
カセット	D1, D4, D7
増設	D2, D3, D5, D7

【図６】

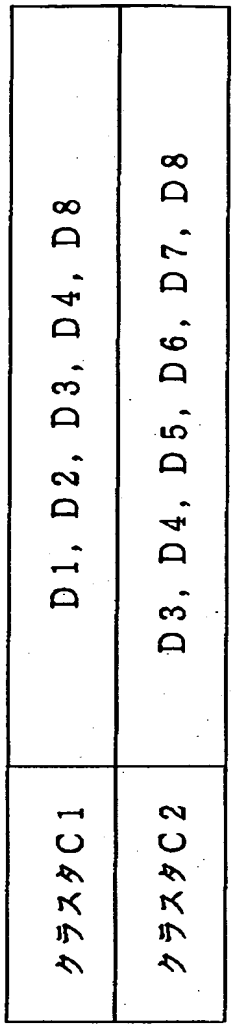

【図７】

特徴要素	クラスタ	
用紙＋カセット	Ｄ１，Ｄ４，Ｄ６，Ｄ７	Ｄ２，Ｄ３，Ｄ５，Ｄ７
増設		

【図８】

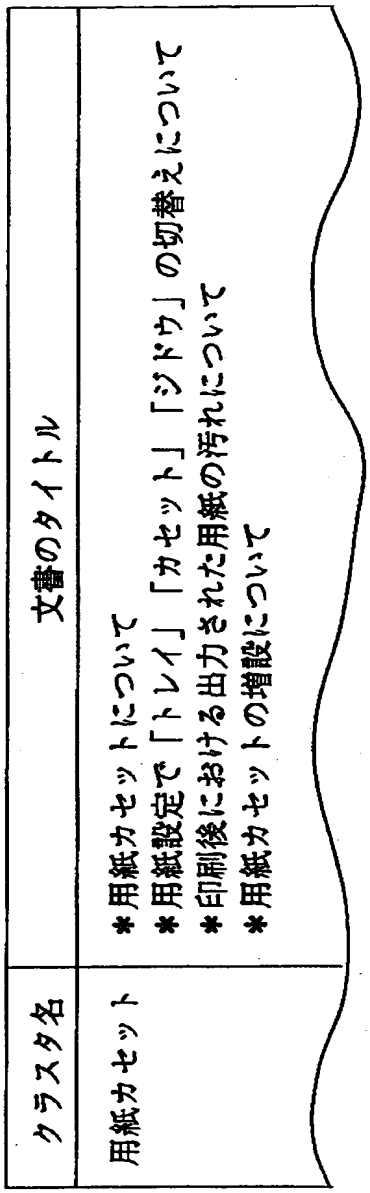
クラスタ名
文書のタイトル
用紙カセット
＊用紙カセットについて
＊用紙設定で「トレイ」「カセット」「ジドウ」の切替えについて
＊印刷後における出力された用紙の汚れについて
＊用紙カセットの増設について

【図９】

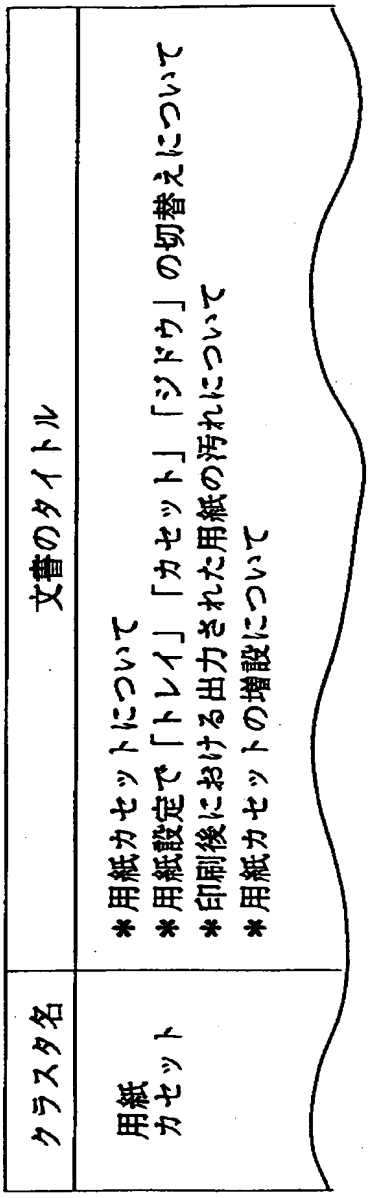
クラスタ名
文書のタイトル
用紙
カセット
＊用紙カセットについて
＊用紙設定で「トレイ」「カセット」「ジドウ」の切替えについて
＊印刷後における出力された用紙の汚れについて
＊用紙カセットの増設について

【書類名】　　要約書

【要約】

【課題】多数の文書をそれぞれの文書に存在する特徴要素に基づいてクラスタに分類する場合、多数のクラスタを整理しわかりやすくして出力する。

【解決手段】それぞれの文書を意味的に共通性を有する複数のクラスタに分類するクラスタリング部１と、得られた複数のクラスタ間でそれぞれのクラスタに含まれる文書に基づいてそれぞれのクラスタの関連性を判断し、一定以上の関連性を有する少なくとも２つのクラスタを統合するクラスタマージ部２と、クラスタマージ処理されて得られた新たなクラスタの表示を行う際、その新たなクラスタに対し、クラスタマージ処理内容がわかるように、どのようなクラスタがどのような関連性を有して統合されたかを示す表示内容を生成するクラスタマージ内容生成部３と、その表示内容をユーザに提示すべき分類結果に含めて出力する分類結果出力手段４とを有する。

【選択図】　　図１

出　願　人　履　歴　情　報

識別番号　　〔０００００２３６９〕

１．変更年月日　　１９９０年　８月２０日
［変更理由］　新規登録
住　所　東京都新宿区西新宿２丁目４番１号
氏　名　セイコーエプソン株式会社